



<https://doi.org/10.34883/Pl.2022.12.2.028>
УДК 617.735-007.281-079.4



Качан Т.В.¹✉, Скрыпник О.В.¹, Курочкин А.В.², Головатая Е.А.², Марченко Л.Н.¹,
Далидович А.А.¹

¹ Белорусский государственный медицинский университет, Минск, Беларусь

² Белорусский государственный университет, Минск, Беларусь

Методы машинного обучения в повышении информативности исследования витреохориоретинального интерфейса у пациентов с периферической ретинальной патологией

Конфликт интересов: не заявлен.

Вклад авторов: проведение исследований и внесение в БД – Скрыпник О.В., Качан Т.В., текст – Качан Т.В., Скрыпник О.В.; создание классификационных моделей – Курочкин А.В., Головатая Е.А., Качан Т.В.; редактирование, выводы – Качан Т.В., Скрыпник О.В., Марченко Л.Н., Курочкин А.В., Головатая Е.А., Далидович А.А.

Подана: 28.03.2022

Принята: 10.05.2022

Контакты: eyeill@bsmu.by

Резюме

Цель. Оценить информативность клинических и параклинических параметров в выявлении периферических ретинальных изменений на основе методов машинного обучения (МО).

Материалы и методы. Проанализирован 21 показатель 249 глаз 171 пациента в возрасте $44,2 \pm 19,55$ года, 32,0% мужчин и 68,0% женщин. Из них – 186 глаз с периферическими изменениями сетчатки и 63 глаза здоровых лиц. Для решения поставленной задачи создано 2 классификационные модели: 1) на основе нейронной сети (НС) прямого распространения; 2) на основе дерева решений (ДР).

Результаты. Глаза пациентов основной группы были стратифицированы в подгруппы: 1) с витреохориоретинальными периферическими дистрофиями (ВХРПД); 2) с периферическим дегенеративным ретиноизисом (ДРШ) 3) с отслойкой сетчатки (ОС), ассоциированной с ДРШ; 4) с регматогенной ОС; 5) с периферическими ретинальными разрывами. Созданные классификационные модели имели следующие характеристики: НС модель – accuracy 0,89; F1-мера 0,88, модель основе ДР – accuracy 0,83, F1-мера – 0,85. С высокой точностью определяли следующие классы: 1) без патологических изменений, 2) с ВХРПД и ДРШ, 3) с регматогенной ОС; 4) с ОС, ассоциированной с ретиноизисом. В обеих моделях самое сильное влияние на результат оказали следующие показатели: циркулярное распространение периферической патологии в градусах, возраст пациента и бинарные показатели, опирающиеся на ОКТ.

Выводы: 1) использование ОКТ существенно повышает эффективность диагностики периферической патологии сетчатки; 2) циркулярное распространение ретинальных изменений и возраст пациентов не должны недооцениваться при выборе тактики их ведения и лечения; 3) методы МО обеспечивают клиницистов ресурсами для

персонифицированных подходов к диагностике, лечению и прогнозированию возникновения заболеваний и их исходов.

Ключевые слова: методы машинного обучения, нейронная сеть, дерево решений, отслойка сетчатки, периферическая дистрофия сетчатки, дегенеративный ретинопатия

Kachan T.¹✉, Skrypnik O.¹, Kurochkin A.², Holovataya E.², Marchenko L.¹, Dalidovich A.¹

¹ Belarusian State Medical University, Minsk, Belarus

² Belarusian State University, Minsk, Belarus

Machine Learning Methods in Increasing the Informativity of the Study of the Vitreochorioretinal Interface in Patients with Peripheral Retinal Pathology

Conflict of interest: nothing to declare.

Authors' contribution: conducting research and entering into the database – Skrypnik O., Kachan T.; writing text – Kachan T., Skrypnik O.; creation of classification models – Kurochkin A., Golovataya E., Kachan T.; editing, conclusions – Kachan T., Skrypnik O., Marchenko L., Kurochkin A., Golovataya E., Dalidovich A.

Submitted: 28.03.2022

Accepted: 10.05.2022

Contacts: eyeill@bsmu.by

Abstract

Purpose. To evaluate the information content of clinical and paraclinical parameters in the detection of peripheral retinal changes based on machine learning (ML) methods.

Materials and methods. 21 parameters of 249 eyes of 171 patients aged 44.2 ± 19.55 years, 32.0% of men and 68.0% of women, were analyzed. Of these, 186 eyes with peripheral changes in the retina and 63 eyes of healthy individuals. To reach the purpose 2 classification models were created: 1) based on a neural network (NN); 2) based on a decision tree (DT).

Results. The eyes of the patients of the main group were stratified into subgroups: 1) with vitreochorioretinal peripheral dystrophies (VCRPD); 2) with peripheral degenerative retinoschisis (DRS); 3) with retinal detachment (RD) associated with DRS; 4) with rhegmatogenous RD; 5) with peripheral retinal ruptures. The created classification models were characterized by: NN model – accuracy 0.89; F1-score 0.88, model-based DT-accuracy 0.83, F1-score: 0.85 and with high accuracy determined the following subgroups: 1) without pathological changes, 2) with CRPD and DRS, 3) rhegmatogenous RD and 4) RD associated retinoschisis. In both models, the most significant influence on the outcome was exerted by indicators: circular spread of peripheral pathology in degrees, patient age, and binary indicators based on OCT.

Conclusions: 1) the use of OCT significantly increases the efficiency of diagnosing peripheral retinal pathology; 2) the circular spread of retinal changes and the age of patients should not be underestimated when choosing tactics for their management and treatment; 3) ML methods provide clinicians with resources for personalized approaches to diagnosing, treating and predicting the occurrence of diseases and their outcomes.



Keywords: machine learning methods, neural network, decision tree, retinal detachment, peripheral retinal dystrophy, degenerative retinoschisis

■ ВВЕДЕНИЕ

Для определения наиболее информативных показателей в постановке диагноза используется множество статистических методов (регрессионный анализ, корреляционный анализ и т. д.). Однако клинические данные не идеальны: могут наблюдаться варьируемые по диапазону значения показателей, зависимость результата (диагноза) от входных данных (исследуемых параметров), как правило, является нелинейной. Решение перечисленных недостатков стало возможным с внедрением во многие области медицины моделей на основе машинного обучения (МО) [1, 2]. Методы МО относятся к области искусственного интеллекта и в последние годы развиваются быстрыми темпами. Они представляют собой статистические модели для классификации данных и прогнозирования в различных прикладных областях. В медицине методы МО могут упростить шаги, связанные с диагностикой заболеваний на основе клинических данных, тем самым обеспечить значительную поддержку врача и оптимизацию рабочего процесса. Благодаря более глубокому статистическому анализу, модели на базе МО способны выявлять болезни, которые не могут быть диагностированы человеком. Эти методы доказали свою эффективность и используются во многих областях медицины, включая офтальмологию, эндокринологию, кардиологию, онкологию, инфектологию и многие другие [3–6].

Модели МО делятся на два типа в зависимости от методов обучения, а именно: с учителем и без учителя. В первом случае, при обучении с учителем, модель МО обучается с набором входных данных, которые связаны с известными выходными данными. После успешного обучения модели МО она способна делать прогнозы на основе новых данных. Прогнозы, полученные с помощью моделей на основе обучения с учителем, могут быть непрерывными или дискретными. Методы обучения без учителя работают с входными данными без каких-либо известных результатов. Они основаны на выявлении структурных различий данных и могут использоваться для уменьшения размеров набора данных путем извлечения из них важных характеристик [7].

Примерами алгоритмов МО являются нейросетевой анализ (НСА), деревья решений (ДР), случайные леса (СЛ) и др. В отличие от пороговой классификации по одному параметру, нейросетевая классификация позволяет для принятия решения использовать совокупности исходных признаков, в том числе нелинейные. Базовым вычислительным узлом в НСА является формальный нейрон, представляющий собой функцию преобразования линейной комбинации (взвешенной суммы) входных признаков в промежуточное выходное значение. В традиционной нейросетевой архитектуре прямого распространения, называемой многослойным персепtronом, отдельные нейроны группируются в слои и выходные значения с каждого из нейронов очередного слоя подаются на каждый из нейронов следующего слоя. Нейросетевой анализ является одновременно и мощным, и гибким методом formalизации процессов, в том числе медицинских [1, 2, 7]. Деревья решений – модель регрессии или классификации, в которой для определения итогового класса

используется иерархическое выстраивание признаков и некоторых подобраных пороговых значений для разметки пространства принятия решений. На верхнем уровне дерево состоит из «вопроса» и двух или более поддеревьев. Выбирается одно из них в соответствии с ответом на вопрос. Сами поддеревья структурированы аналогичным образом. Обычно в качестве вопроса используется сравнение значения того или иного признака с некоторым искусственно подбиаемым порогом. Построение ДР происходит на основании последовательного выбора признака и порога по информационному критерию с использованием одного из алгоритмов построения дерева [6, 7]. В целом деревья не поддерживают такой же гибкой настройки, как нейронные сети (НС), однако успешно используются в различных прикладных областях как более вербализуемые и интерпретируемые аналитические модели.

Данное исследование посвящено анализу наиболее распространенных периферических изменений сетчатки с помощью методов МО. Выявление информативных показателей потенциального развития отслойки сетчатки (ОС) сводится к обработке большого количества разнородного, трудноформализуемого материала, который лежит в диапазоне от социально-гендерных показателей до анализа особенностей витреоретинального интерфейса по данным оптической когерентной томографии (ОКТ).

■ ЦЕЛЬ ИССЛЕДОВАНИЯ

Оценить информативность клинических и параклинических параметров в выявлении периферических ретинальных изменений на основе методов машинного обучения.

■ МАТЕРИАЛЫ И МЕТОДЫ

В исследование отобрано 249 глаз 171 пациента в возрасте $44,2 \pm 19,55$ года, из них 32,0% мужчин и 68,0% женщин. В основную группу вошли 186 глаз с периферическими изменениями сетчатки, в контрольную группу – 63 глаза здоровых лиц, соответствующих основной группе по возрасту и полу. Пациентам проводилось полное офтальмологическое обследование, включающее визометрию, авторефрактометрию, пневмотонометрию, осмотр на щелевой лампе, исследование глазного дна с фундус-линзой (ФЛ), ОКТ, В-сканирование. Осмотр на щелевой лампе осуществлялся на аппарате Carl Zeiss. Для осмотра глазного дна с ФЛ использовалась трехзеркальная линза Гольдмана. В-сканирование проводилось на ультразвуковом офтальмологическом В-сканере Tomey UD 8000. Для проведения time-domain ОКТ применялась система Stratus OCT 3000 (Carl Zeiss Meditec) с источником света длиной волны 820 nm. Для проведения ОКТ с функцией ангиографии и спектральным способом построения изображений использовался Revo 80 (Optopol, Польша) с программным обеспечением AngioVue, источником света 840 nm. База данных, созданная в Excel, объединяла клинические и параклинические параметры, где строки соответствовали наблюдениям (глаза), а столбцы соответствовали изучаемым показателям. Анализу подвергся 21 показатель, описание представлено в табл. 1.

Сформированные на основе подгрупп классы представлены в табл. 2.

Для решения поставленной задачи создано 2 классификационные модели: 1) на основе НС прямого распространения; 2) на основе ДР. Классификационная модель

**Таблица 1****Описание показателей, которые анализировались методами МО****Table 1****Description of indicators that were analyzed by ML methods**

Описание показателя	Обозначение показателя в базе данных
Вместо даты рождения и даты обследования использовалось количество дней между датой обследования и датой рождения, пронормированное на 365 000 (100 лет)	Exam
Жалобы. Представлены: 1) «летающие точки»; 2) вспышки; 3) «летающие точки» + вспышки; 4) затуманивание; 5) отсутствие жалоб	Complaints
Максимально корrigированная острота зрения	BCVA
Локализация периферических изменений по отделам: 1) верхний; 2) нижний; 3) темпоральный; 4) назальный; 5) верхне-темпоральный; 6) верхне-назальный; 7) нижне-темпоральный; 8) нижне-назальный	Localization
Циркулярное распространение периферических изменений в градусах: 1) 30°; 2) 60°; 3) 90°; 4) 120°; 5) 150°; 6) 180°. Ориентиром служил циферблат часов, пропорциональность 1-го часа эквивалентна 30°	Size
Рефракция. Представлена: 1) эмметропия; 2) миопия слабой степени; 3) миопия средней степени; 4) миопия высокой степени; 5) гиперметропия	Refraction
Бинарные показатели	
Пол: 1) мужской; 2) женский	Sex
1) есть разрыв; 2) нет разрыва	Break
1) дегенеративный ретиношизис (ДРШ) выявлен при проведении ОКТ; 2) ДРШ не выявлен при проведении ОКТ	RetSh_OCT
1) ДРШ выявлен при осмотре с ФЛ; 2) ДРШ не выявлен при осмотре с ФЛ	RetSh_F_L
1) наличие разрыва в пределах ДРШ; 2) отсутствие разрыва в пределах ДРШ	BrRetSh
1) ОС, ассоциированная с ДРШ, выявлена по результатам ультразвукового В-сканирования; 2) ОС, ассоциированная с ДРШ, не выявлена по результатам ультразвукового В-сканирования	AblRetSh_OCT
1) ОС, ассоциированная с ДРШ, выявлена по результатам осмотра с ФЛ; 2) ОС, ассоциированная с ДРШ, не выявлена по результатам осмотра с ФЛ	AblRetSh_FL
1) витреоретинальная тракция (ВРТ) выявлена при проведении ОКТ; 2) ВРТ не выявлена при проведении ОКТ	VitrRetTraction_OCT
1) ВРТ выявлена при осмотре с фундус-линзой; 2) ВРТ не выявлена при осмотре с фундус-линзой	VitrRetTraction_F_L
1) ВРТ выявлена по результатам ультразвукового В-сканирования; 2) ВРТ не выявлена по результатам ультразвукового В-сканирования	VitrRetTraction_Bsc
1) ОС выявлена при проведении ОКТ; 2) ОС не выявлена при проведении ОКТ	Abl_OCT
1) ОС выявлена при осмотре с ФЛ; 2) ОС не выявлена при осмотре с ФЛ	Abl_F_L
1) ОС выявлена при проведении ультразвукового В-сканирования; 2) ОС не выявлена при проведении ультразвукового В-сканирования	Abl_Bsc
1) задняя отслойка стекловидного тела (ЗОСТ) выявлена с помощью ОКТ Spectralis; 2) ЗОСТ не выявлена с помощью ОКТ Spectralis	PVD_OCTA
1) ЗОСТ выявлена при проведении ультразвукового В-сканирования; 2) ЗОСТ не выявлена при проведении ультразвукового В-сканирования	PostVitrDet_B

на основе НС прямого распространения имела следующие характеристики: 2 скрытых слоя на 100 и 50 нейронов, функцию активации ReLU, оптимизацию модели методом Бродбена – Флетчера – Голдфарба – Шанно с ограничением по памяти (LBFGS) [9]; разделение на обучающую и тестовую выборку произведено в соотношении

Таблица 2
Описание периферических изменений сетчатки и сформированных на его основании классов
Table 2
Description of peripheral changes in the retina and the classes formed on its basis

Периферические изменения сетчатки	N (количество глаз)	Класс	Обозначение класса в базе данных
Отсутствие изменений (здоровые лица)	63	0	N
Витреохориоретинальная периферическая дистрофия (ВХРПД)	48	1	VHRD
ДРШ	59	2	RetSh
Регматогенная ОС	34	3	AR
ОС, ассоциированная с ДРШ	20	4	RetSh + AR
Клапанный разрыв	6	5	Horse
Дырчатый разрыв	19	6	Tear

70%/30%. [7, 9]. Дерево решений представлено: модель – CART, информационный критерий – коэффициент Джини без ограничения глубины; разделение на обучающую и тестовую выборку в соотношении 70%/30% [7, 8].

Для оценки качества классификации использовались следующие показатели:

1. Точность (accuracy) – определялась как доля элементов выборки (наблюдений), которая была классифицирована корректно.
2. Прогностическая значимость положительной классификации, positive predictive value (PPV), в англоязычной литературе используется термин «precision», который в некоторых русскоязычных источниках также переводится как «точность», что приводит к путанице с термином «accuracy». PPV – это доля элементов (наблюдений), действительно принадлежащих данному классу относительно всех случаев, которые классификатор отнес к этому классу: $PPV = \frac{TP}{TP + FP}$, где TP – истинно положительные результаты, количество элементов (наблюдений) данного класса, которые классификатор корректно отнес к данному классу; FP – ложноположительные результаты, количество элементов (наблюдений) другого класса, которые классификатор ошибочно отнес к данному классу. Чем ближе значение PPV к 1, тем меньше ошибок первого рода (ложноположительных результатов) допустил классификатор. Значение, близкое к 0, указывает на то, что большинство результатов, определенных классификатором как положительные, были классифицированы некорректно.
3. Чувствительность (sensitivity, в англоязычной литературе также используется термин «recall», который в русскоязычных источниках переводят как «полнота»). Recall определялся как доля элементов, корректно отнесенных к данному классу среди всех элементов, которые должны были быть отнесены к данному классу: $Recall = \frac{TP}{TP + FN}$, где FN – ложноотрицательные результаты (количество элементов данного класса, которые классификатор ошибочно отнес к другому классу). Чем ближе значение чувствительности к 1, тем меньше ошибок второго рода (ложно-отрицательных результатов) допустил классификатор. Значение, близкое к 0, указывает на то, что большинство результатов, определенных классификатором как отрицательные (не принадлежащие данному классу), были классифицированы некорректно. Таким образом, использование показателей PPV и Recall позволяло характеризовать качество классификации как с точки зрения положительных, так



и с точки зрения отрицательных результатов классификации. В реальных условиях максимальная точность и полнота чаще всего одновременно не достижимы, а анализ двух отдельных показателей не всегда является достаточным для оценки итоговой модели. В связи с этим целесообразно использовать метрику, которая объединяла бы в себе информацию о PPV, и о Recall – именно такой метрикой является F1-мера (F1-score) [10, 11].

4. F1-мера определяется как гармоническое среднее между PPV и Recall: $F1=2 \frac{PPV \times R}{PPV + R}$. Таким образом, F1-мера принимает значение, равное 1, только если классификатор не допустил ни одной ошибки, и значение, равное 0, если классификатор совершил максимальное возможное количество ошибок либо первого, либо второго рода.

Для визуализации качества работы классификатора относительно всех классов на выборке использовалась матрица запутывания (confusion matrix), или матрица ошибок. В такой матрице по строкам указывались значения классов, которые ожидались, а по столбцам – классы, которые были предсказаны классификатором. Значение в ячейке в i-й строке и в j-м столбце соответствовали количеству элементов, которые имели ожидаемый класс i и были предсказаны классификатором как класс j. Таким образом, диагональные элементы матрицы запутывания (для которых i=j) отображали количество корректно определенных элементов соответствующего класса, а все недиагональные элементы соответствовали ошибкам, когда ожидаемый класс i был ошибочно принят за другой класс j. Благодаря представлению в виде матрицы можно было не только оценить долю ошибочных предсказаний, но и определить, какие из классов классификатор может перепутать друг с другом и насколько часто это происходит.

■ РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

По результатам исследования глаза пациенты основной группы были стратифицированы на подгруппы в соответствии с табл. 2. Следует отметить, что группа глаз с регматогенной ОС объединила:

- 1) глаза пациентов, у которых сразу при первичном обследовании на основании осмотра с ФЛ и ультразвукового В-сканирования была диагностирована ОС (n=20);
- 2) глаза пациентов, которые долгое время наблюдались с диагнозом ДРШ, однако проведенная ОКТ выявила регматогенную ОС (n=11).

Итоговые метрики классификационной модели на основе НСА следующие: accuracy – 0,89; средневзвешенная F1-мера – 0,88. Метрики, оценивающие эффективность, с которой нейросетевая классификационная модель распознавала каждый класс, представлены в табл. 3.

Таблица 3

Метрики по каждому из классов на обучающей выборке НСА

Table 3

Metrics for each of the classes on the training sample of the neural network analysis

	0	1	2	3	4	5	6
PPV	1.00	1.00	0.81	0.73	0.83	1.00	0.80
Recall	0.95	0.93	0.94	0.80	0.83	0.50	0.67
F1-score	0.97	0.96	0.87	0.76	0.83	0.67	0.73

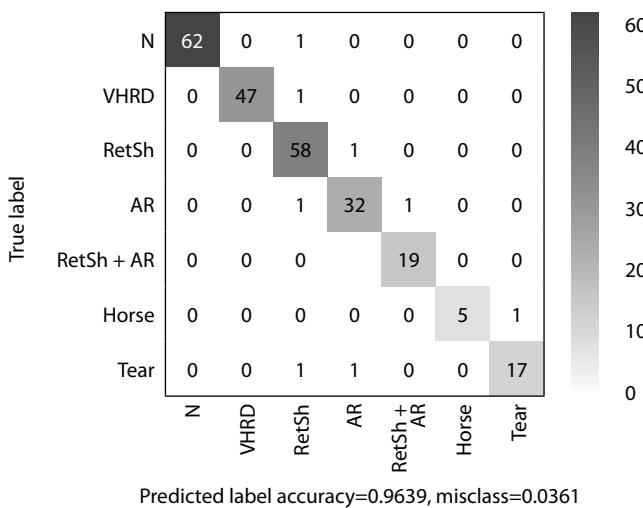


Рис. 1. Матрица запутывания нейросетевой классификационной модели на всей выборке
Fig. 1. Confusion matrix of the neural network classification model on the entire sample

Из полученных результатов следует, что наиболее точно представленные показатели характеризуют 0-й класс – глаза без патологических изменений, а также 1-й и 2-й класс – глаза с ВХРПД и ДРШ. Также высокая точность и чувствительность определены у классов 3 и 4 – регматогенной ОС и ОС, ассоциированной с ретинонекрозом. Таким образом, клиническое использование представленных параметров дает возможность с весьма высокой точностью дифференцировать представленные классы. Чувствительность менее 70% определена только у 5-го и 6-го классов – глаза соответственно с клапанным и дырчатым разрывами. Возможно, это связано с наличием сочетания разрывов с ВХРПД и ОС, отнесенных к другим классам, так как данные классы включали только глаза с «чистыми разрывами», то есть без ОС и ВХРПД.

Визуализация качества работы нейросетевого классификатора в виде матрицы запутывания представлена на рис. 1.

Представленная матрица ошибок демонстрирует высокую диагностическую точность в выявлении каждого класса на основе нейросетевой классификационной модели. Таким образом, использование в диагностике периферических патологических изменений сетчатки параметров, полученных с помощью ОКТ, осмотра с ФЛ и ультразвукового В-сканирования, с учетом гендерно-возрастных характеристик объектов исследования позволяет с точностью, близкой к 100%, дифференцировать каждый класс.

С целью определения, какие из исследуемых параметров наибольшим образом влияют на результат, и таким образом оценки их клинической значимости был осуществлен перебор комбинаций данных признаков с включением [12]. Для каждого показателя определялась сумма F1-score всех классификаторов, в которых использовался этот признак. Результат представлен на графике (рис. 2).

Таким образом, в классификационной модели на основе НСА самое сильное влияние на результат оказывали два признака: Exam и Size. Далее в порядке убывания влияния на результат: RetSh_OCT и RetSh_F_L, затем следовал показатель

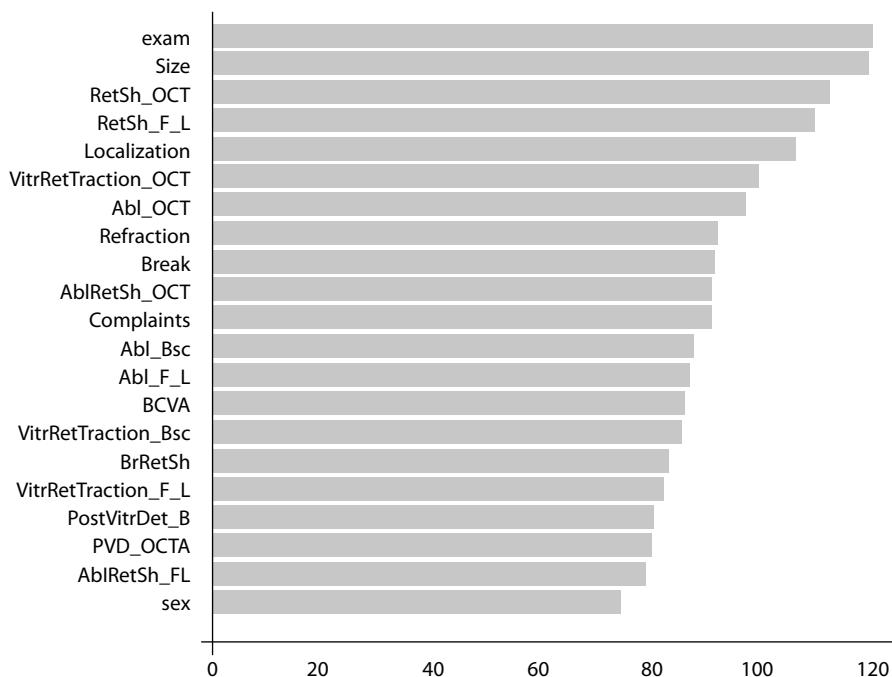


Рис. 2. Графическое представление значимости используемых признаков по суммарной F1-мере при включении признака

Fig. 2. Graphical representation of the significance of the features used by the total F1-score when the feature is included

Localization, за ним – показатель VitrRetTraktion_OCT, далее – Abl_OCT, Refraction, Break, AblRetSh_OCT и Complaints. Более слабое влияние на результат оказывали показатели: Abl_Bsc, Abl_F_L, еще слабее – показатели BCVA, VitrRetTraktion_Bsc, BrRetSh, VitrRetTraktion_F_L, PostVitrDet_B, PVD_OCTA, AblRetSh_FL. И, наконец, самое слабое влияние на результат оказал показатель sex.

Данные результаты важны как для более глубокого понимания сути происходящих периферических изменений сетчатки, так и тактики ведения таких пациентов. Они выявляют скрытые, неочевидные взаимосвязи между признаками, расширяя возможности клиницистов. Так, например, возраст не является ведущим фактором в определении тактики лечения либо показаний к тому или иному способу лечения, при этом его вес в корректной работе нейросетевых классификаторов наиболее высок. Более того, полученные результаты указывают на высокую ценность показателя циркулярного распространения патологических периферических изменений сетчатки. На результат работы классификаторов также существенное влияние оказывает ряд показателей ОКТ и осмотра с ФЛ. Интересным и неожиданным представляется тот факт, что наличие разрыва в тех или иных патологических периферических состояниях сетчатки в меньшей степени влияет на результат, чем локализация изменений либо рефракция исследуемого глаза.

Таблица 4

Метрики по каждому из классов на обучающей выборке дерева решений

Table 4

Metrics for each of the classes on the training sample of the decision tree

	0	1	2	3	4	5	6
PPV	0.90	0.92	0.92	0.64	0.75	1.00	1.00
Recall	1.00	0.86	0.67	0.90	1.00	0.50	0.83
F1-score	0.95	0.89	0.77	0.75	0.86	0.67	0.91

Итоговые метрики классификационной модели на основе ДР близки к таковым нейросетевой модели: accuracy – 0.83, средневзвешенная F1-мера – 0.85. Метрики по каждому из классов на обучающей выборке представлены в табл. 4.

При сравнении полученных результатов с таковыми в нейросетевой классификационной модели следует отметить, что в модели на основе ДР также представленные показатели наиболее точно характеризуют 0-й класс (глаза без патологических изменений) и 1-й класс (ВХРПД). Также высокая чувствительность определена у классов: 3 (регматогенная ОС) и 4 (ОС, ассоциированная с ретинонекрозом). Аналогично обе модели классифицируют 5-й класс (клапанный разрыв) – PPV равна 1,00, а чувствительность менее 70%. Отличия определены: 1) для 6-го класса (дырчатый разрыв) – в модели на основе ДР для этого класса чувствительность составила 83,3% при ее значении менее 70% (50,0%) у нейросетевой модели; 2) для класса 2 (ДРШ) – в модели на основе ДР чувствительность оказалась менее 70% при высокой чувствительности (94,4%) в нейросетевом классификаторе. Оба классификатора продемонстрировали высокое значение F1-score для всех классов, кроме 5-го (<70%).

Визуализация качества работы классификатора на основе ДР в виде матрицы запутывания представлена на рис. 3.

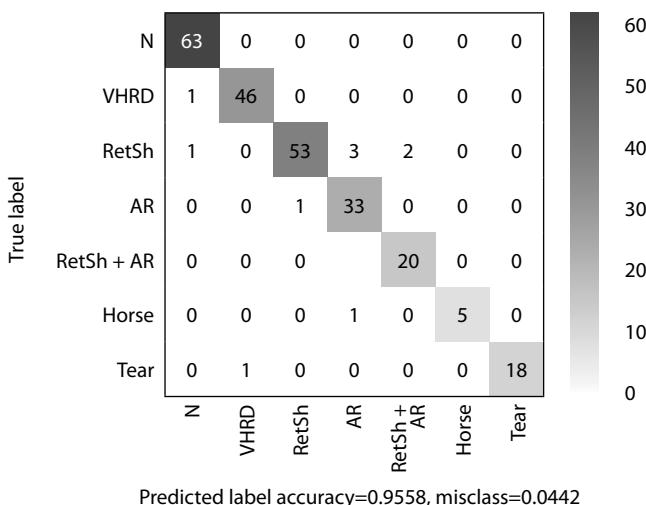


Рис. 3. Матрица запутывания классификационной модели на основе ДР на всей выборке
Fig. 3. Confusion matrix of the DT-based classification model for the entire sample

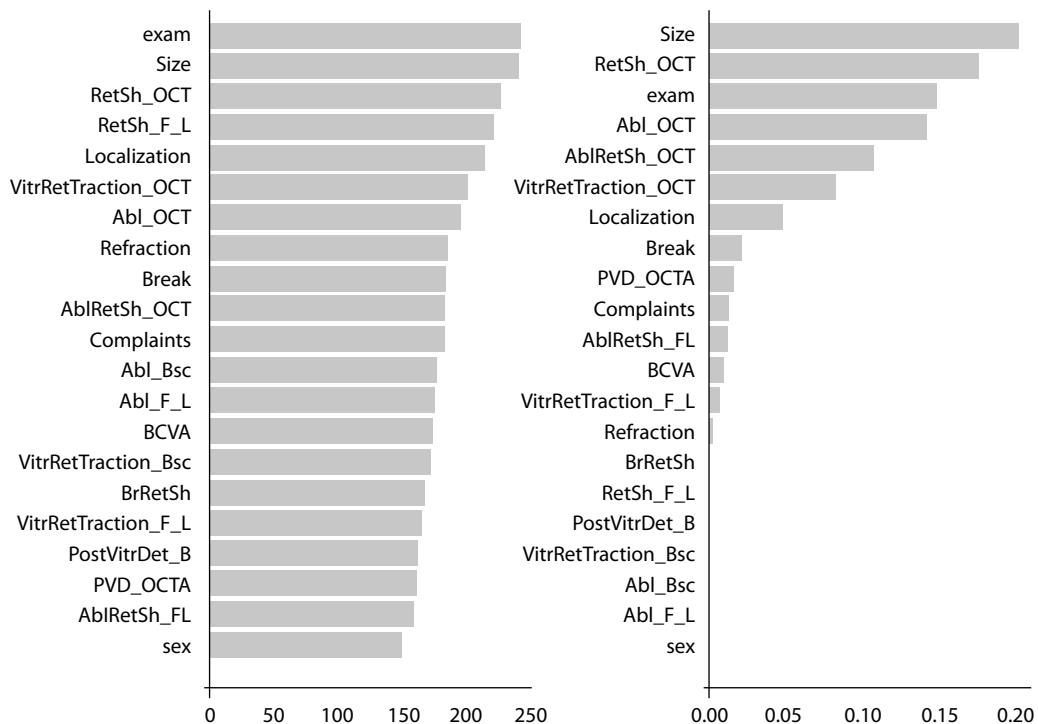


Рис. 4. Графическое представление значимости используемых признаков по суммарной F1-мере при включении признака (слева – ненормированная, справа – по информационному критерию самого дерева)

Fig. 4. Graphical representation of the significance of the features used by the total F1-score when the feature is included (on the left – unnormalized, on the right – by the information criterion of the tree itself)

К моделям на основе ДР для оценки значимости признаков можно применять аналогичный нейросетевым моделям подход – оценивать корректность модели при включении признака в одной из комбинаций либо оценивать суммарное снижение корректности при исключении признака в одной из комбинаций. С другой стороны, поскольку модели на основе ДР и СЛ, в отличие от нейросетевой модели, используют некоторый информационный критерий на этапе выбора точки разбиения по очередному признаку, значения этого критерия также можно использовать для оценки значимости признаков. Оценка влияния признаков при использовании дерева (ненормированная) и оценка по информационному критерию самого дерева представлены на рис. 4.

Оценка влияния признаков на результат (ненормированная) при использовании ДР путем перебора комбинаций признаков с включением выявила практически полную аналогию с нейросетевым классификатором. А вот оценка по информационному критерию самого дерева определила самое сильное влияние на результат у

параметра циркулярного распространения (Size), затем – у параметра RetSh_OCT, на третьем месте – возраст, после – в порядке убывания три параметра, опирающихся на ОКТ: Abl_OCT, Abl_RetShOCT и VitrRetTraction_OCT; затем в порядке убывания – Break, PVD_OCTA, Complaints, AblRetSh_FL, BCVA, VitrRetTraction_F_L и Refraction. Остальные параметры при построении дерева в соответствии с оценкой по информационному критерию влияния на результат не оказали.

Таким образом, полученные результаты, с одной стороны, подтвердили интуитивно очевидные для клинициста представления о высокой информативности ОКТ в изучении витреоретинального интерфейса и необходимости ее широкого использования в диагностике периферической патологии ретины, с другой стороны, обратили внимание на ранее совсем не очевидные результаты. К ним относятся высокая информативность таких показателей, как циркулярное распространение патологических изменений, определяемое в градусах, и возраст пациентов. Несомненно, полученные данные необходимо изучать в дальнейшем на других классификационных моделях, а также учитывать в выборе тактики ведения и лечения каждого конкретного пациента.

■ ВЫВОДЫ

1. Для оценки информативности параметров, характеризующих периферический витреоретинальный интерфейс, создано две классификационные модели на основе методов МО – нейросетевая и на основе ДР. Итоговые метрики полученных классификационных моделей продемонстрировали высокую точность (accuracy 0,89; F1-score 0,88) для нейросетевого классификатора и для классификатора на основе ДР (accuracy 0,83, F1-score 0,85).
2. Из периферических патологических изменений с наибольшей точностью обеими полученными моделями определялся класс витреохориоретинальных периферических дистрофий (Recall 0,93, F1-score 0,96 для нейросетевого классификатора, Recall 0,86, F1-score 0,89 для классификатора на основе ДР).
3. В обеих моделях на основе перебора комбинаций признаков с включением самое сильное влияние на результат оказали 2 параметра: циркулярное распространение патологических изменений и возраст пациента.
4. Оценка исследуемых параметров по информационному критерию самого дерева определила самое сильное влияние на результат у параметра циркулярного распространения патологических периферических изменений. При этом наиболее значимое влияние на результат оказывали параметры, опирающиеся на ОКТ, а также возраст пациента.
5. Очевидно, что использование ОКТ существенно повышает эффективность диагностики периферической патологии сетчатки. При этом такие факторы, как циркулярное распространение ретинальных изменений и возраст пациентов, не должны недооцениваться при выборе тактики их ведения и лечения.
6. Методы МО обеспечивают клиницистов ресурсами для персонифицированных подходов как к диагностике и лечению различных заболеваний сетчатки, так и прогнозированию их возникновения и исходов.



■ ЛИТЕРАТУРА/REFERENCES

1. Aravin O. *Russian Journal of Biomechanics*. 2011;15(3):45–5146. (in Russian)
2. Yasnitskii L. *Intelligent systems*. Moscow: Laboratoriya znanii. 2016;221. (in Russian)
3. Alic B., Gurbeta L., Badnjević A. *Machine learning techniques for classification of diabetes and cardiovascular diseases*. 6th mediterranean conference on embedded computing (MECO). 2016;1–4.
4. Apostolopoulos I.D., Mpesiana T.A. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*. 2020;43:635–640.
5. Ausawalithong W., Thirach A., Marukatat S., Wilaiprasitporn T. *Automatic lung cancer prediction from chest x-ray images using the deep learning approach*, in: 2018 11th Biomedical Engineering International Conference (BMEICON), IEEE. 2018;1–5.
6. Alsaaf R.A., Alsulaim K.A., Alrooomi N.Y., Alsharif N.S., Aljubeir M.F., Olatunji S.O., Alahmadi A.Y., Imran M., Alzahrani R.A., Alturayef N.S. *Preemptive diagnosis of diabetes mellitus using machine learning*. Proceedings of the 2018 21st Saudi Computer Society National Computer Conference (NCC); Riyadh, Saudi Arabia. 25–26 April 2018. 1–5 pp.
7. Russel St., Norving P. *Artificial Intelligence: A Modern Approach (Pearson Series in Artificial Intelligence)*. 4th ed. Pearson, 2020;1136.
8. Breiman Leo, Friedman J.H., Olshen R.A., Stone C.J. *Classification and regression trees*. Monterey, CA: Wadsworth & Brooks/Cole Advanced Books & Software. 1984.
9. Liu D.C., Nocedal J. On the Limited Memory Method for Large Scale Optimization. *Mathematical Programming B*. 1989;45(3):503–528. CiteSeerX 10.1.1.10.6443. doi: 10.1007/BF01589116. S2CID5681609.
10. Hastie T., Tibshirani R., Friedman J. *The Elements of Statistical Learning: Data Mining, Inference and Prediction*. Springer Series in Statistics, Springer-Verlag. New York. 2009;745.
11. Powers D. Evaluation: from Precision, Recall and F-measure to ROC, Informedness, Markedness & Correlation. *Journal of Machine Learning Technologies*. 2011;2:137–63.
12. Kurochkin A., Sadau V., Kachan T. *Decision-making process analysis and semantic explanation extraction from trained supervised machine learning models in medical expert systems*. Open semantic technologies for intelligent systems: research papers collection. Belarusian state university of informatics and radioelectronics. Minsk, 2020;4:283–286.